

論 説

AI 管理会計に関する理論的研究

—将来予測とフィードフォワードへの AI の適用—

谷 守 正 行

はじめに

AI が着実に実用化されている。今回は、過去の AI やロボットなどの SF の世界を期待するようなブームと違って、ビジネス上かつ人間しか行えないと思われていた企業内で行われる「業務」へ導入されて、現実には収益の向上や資源の効率化などの企業価値向上に有効性が認められつつあるのが特徴的である。

とくにそのなかでも、市販の会計ソフトにおいて仕訳から財務諸表作成までの簿記・仕訳の処理に AI の適用が相当な勢いで行われている。たとえば、AI が銀行口座の入出金データやレシートなどのデータを自動で読み取って仕訳を行い、財務諸表が自動的に作成できるようになっている。最近では、残高試算表や仕訳帳を証票と照合し、月次試算表を作成するといったチェック業務まで、AI による自動化が実現している。

ただし、いま話題となっている業務へ適用される AI は、答えやルールの決まった処理の自動化である。これまでコンピュータ上でプログラミングによって処理されてきたのは、与えられたデータの特徴に従って、計算などの手続きを行って処理を行うことであった。データの特徴はプログラムによってロジックが規定されていなければならなかった。

ところが、最近の業務へ適用されている AI は、このデータから特徴量を抽出する処理をプログラムする必要がないというのが特徴である。AI は、結果から遡って自分で自動的に判断のための特徴量を“抽出”することができるの

である。そのため、人間がなんとなく行っていることが、具体的にしなくても AI であれば、同じような処理を行ってくれるのではないかと期待されるのである。すなわち、答えやルールが唯一無二で明確であればあるほど、AI 化しやすい処理といえる。

対して、管理会計への AI 適用はどうなるであろうか。日商簿記試験にあるように、工程別原価計算を行って唯一の答えを算出することが管理会計の 1 つの機能であるが、その場合は最初の与えられた情報から「特徴を読み取る」ことだけがポイントとなる。与えられた問題の資料から特徴さえつかめれば、計算自体はプログラミングであり AI を適用するまでもないからである。

さらに、管理会計が経営のための会計と言われるように、いまの状況を把握して、将来予測を行い、最適な打ち手を取るといったプロセスがある。はたして、このような管理会計プロセスに、AI の機能が適用可能であろうか。

そこで、まず AI の特徴を明らかにする。次に、管理会計のうち原価見積、予算管理、そして意思決定への AI の機能の適用可能性を検討する。とくに、将来予測の原価見積、将来予測に基づくマネジメント・コントロールの予算管理、そして代替案を比較して最適案を選択する意思決定会計を対象に AI の機能の適用可能性を検討する。

最後に、AI の適用によって実現が期待される管理会計機能と、適用のための課題を明らかにする。なお、本稿では AI のアルゴリズムを「機械学習」とし、さらに 2012 年にブームを起こした「ディープ・ラーニング」(deep-learning; 深層学習)を念頭に置いて検討を行う。

1. AI の進化と特徴

市場では AI ブームに沸いている。企業にとってはビジネスチャンスでもあるし、ユーザ側にとっても AI への期待度は夢物語が現実化する思いから相当に高くなっている。そもそもこれまでの AI ブームとどう違うのだろうか。AI とは artificial intelligence の略であるが、AI という言葉が初めて使われたのは、当時ダートマス大学で助教授であったジョン・マッカーシーが 1956 年の

ダートマス大学での会議の場で「人間が抱える問題を解き、自身を改善してくれる機械」という意味で議論した時とされる。このように始まった AI は、あたかも牛歩のように少しずつであるが着実に進化していく。今回の AI ブームは 3 度目である。以下に、それぞれの AI ブームの変遷とともに AI がどのように進化してきたかを整理する。

(1) AI の進化

第 1 次 AI ブームは、1950 年代後半～1970 年代にあった。第 1 次 AI ブームの特徴は「推論と探索」であった。1964 年の東京オリンピックで使われた IBM 360 の大型コンピュータシステムが三井銀行（現三井住友銀行）に譲り受けられて導入されるなど、世界中でコンピュータ黎明期と呼ばれる時代でもあった。

ただし、当時はプログラムを前提に研究されていたため、すべて人間がそのロジックをプログラミングしなければならなかった。さらに、当時のコンピュータ技術では十分にニューロコンピュータを活かすことはできなかったため、徐々に第 1 次 AI ブームは冷めていくことになった。

次に、1980 年代になると、知識データベースを持つエキスパートシステムが現れ、その実用化が AI の第 2 次ブームとなった。第 1 次 AI ブームと同時期の 1970 年代にすでに発案されていたファジーの適用も同時に検討された。ファジーとは、あいまいさを判断のなかに取り込んだ推論方式である。現在の AI にもファジーの考え方が活かされている。エキスパートシステムは、知識と推論が区別されており、知識のデータベースである知識ベースに多くのデータを蓄積すればするほど、的確な判断が行えるはずと考えられた。日本でも第 5 世代コンピュータとして 1982 年から 1992 年までの国家プロジェクトがあり、莫大な予算が投入されたものの、結果は芳しいものではなかった。

ただし、当時は RDB（リレーショナル・データベース）を前提に人間の知識を明文化して、データとルールに落とし込む方式であったため、その作業は相当に難しいものであった。実際には、ほとんどの企業で導入が検討されたエ

キスパートシステムは頓挫した。当時を振り返ると、その要因は次の3つの問題があったからと考えられる。

1つ目の問題は、文章（テキスト）によるノウハウや知識などの情報を扱うには当時のコンピュータでは十分ではなかった。とくに検索機能が極めて低レベルであった。

2つ目の問題は、RDBのデータベース容量が相当に小さく、きわめて高額であったことにある。

3つ目の問題は、エキスパートシステム自体の問題であるが、基本的には「if-then else」の2分岐探索であり、あいまいさであったり、元に戻って再度判断するなどのロジックを構成したりしにくいものであった。つまり、一度判断すると再び判断されることはないシーケンシャルな判断ロジックであったため、一度判断がずれるとどんどんずれが大きくなり、軌道修正しにくい構造であった。結果として、1990年代後半には第2次AIブームは下火になっていった。

そして、最近の第3次AIブーム到来となる。それはすべて、「ディープ・ラーニング」が実用化されてきたことにある（情報処理推進機構, 2017）。これまでのAIでは、パラメータ値の精度を上げて学習させていくのに対して、ディープ・ラーニングは入力パラメータを何にするかまで自己学習していくところが最も大きな違いである。例えば将棋でいえば、今までのAIであれば、各駒の強さや特徴、駒の位置などのパラメータを外から人間が設定し、そのパラメータの最適値を大量の棋譜データを取り込ませることによって学習させるため、人間の設定するパラメータ値が重要な要素であった。それに対して、ディープ・ラーニングでは大量の棋譜データから、逆に入力されるパラメータ値そのものがなくとも自己学習することができるようになったのである。

そのおかげで、テキスト（文章）、音楽、画像など構造化されていない情報、すなわち非構造化データが取り扱われるようになった。さらに、事前にルールを決めて、人間がそのルール自体を教える必要がなくなったのである。

なぜなら、ディープ・ラーニングによって AI 自ら学習してルールや法則を見つけ出せるようになったからである。

たとえば、インターネットの Google 翻訳で英語を和訳した文章が、ほかの相当高価な有料翻訳パッケージソフトよりも格段に読みやすいことが分かる。すなわち、非構造化データにもとづく処理が行えるようになったことが第3次 AI ブームの特徴の1つである。

非構造化データを処理できるようになったことが、AI の実用化に大きな期待を寄せる最大の要因と言ってもよいのではないだろうか。おそらく、どんなにすばらしいディープ・ラーニング機能を備えた AI システムであったとしても、0 か 1 しか処理できないとしたら、ここまで世界中で AI が話題にならず、ましてや実用化はまだずっと先のことと考えられていたであろう。

非構造化データの処理が進んだのは、2010 年ごろからマーケティングの世界で話題となった「ビッグデータ分析」と無縁ではない。なぜなら、ビッグデータの本来の意味は、大量のデータということだけではない。それまで、コンピュータは定量的な数値情報を中心とする構造化データのみを処理の対象としてきたが、文章や画像など RDB（リレーショナル・データベース）やスプレッドシートなどの構造化ファイルを超えて、きわめて莫大な非構造化データまでも処理の対象とすることができたので、ビッグデータ分析といわれるようになったのである。

ここで AI の進化をもとに、AI の特徴をまとめる。現状ブームと言われる通り、AI という言葉は独り歩きしている感がある。主にディープ・ラーニングを中心とする機械学習の会計への適用状況は、入力業務やチェック業務が中心である。AI による会計監査業務支援や不正検知もチェック機能と言って良い。谷守（2018b）で指摘した通り、これまでの会計への AI の適用は定型業務¹が中心で、ロジックが明確な業務である。最近では、RPA（Robotic Proc-

1 実際のところ、例外処理に対しては人間の処理が必要とされている。ただし、時間をかけて例外処理のデータが増えてくれば、AI は学習して例外処理が例外処理ではなくなるかもしれない。

ess Automation) が企業の本部業務に適用されて、効率化や自動化が行われている。RPA は一部 AI が適用されているものもあるが、事前プログラミング型によるものが多く、第3次 AI ブームの最大の特徴である機械学習ではない。ただし、最近の AI とはいえなくとも、定型業務を自動化する RPA は、ミスも疲れもなく同様の単純処理を瞬時に数多くこなすので、企業にとっては大変に重宝がられている。

このように、これまで会計に適用される AI は、主に正解のある定型的な問題を解くことに適用されてきた。管理会計でも実際原価や収益計算するだけなら同様に適用は可能であろう。しかし、管理会計は過去の分析だけではない。将来予測やコントロール機能への AI の適用可否を検討することが重要である。次節では、とくに管理会計への適用の観点から、AI に求められる特徴を明らかにする。

(2) エキスパートシステムとディープ・ラーニングとの違い

第2次 AI ブームでは、エキスパートシステムの実用化が期待された。結局のところ実用化は叶わなかったわけであるが、その際すでに if-then else 型の演繹的推論は完成していた。筆者はバブル崩壊直前の時期に銀行で審査エキスパートシステムの開発に携わっていた。そのプロジェクトは結局のところ中止となったが、いまのディープ・ラーニングの機能や環境と比べて、その要因をまとめると次の3つになる。

1つは IT 環境が未熟であったからである。1990 年代前半はまだ PC 環境が整っていなかった。OS は MS-DOS、小容量のデータベース、低速度の CPU、そしてなにより高額であった。結果、サンプルデータを対象とした推論、すなわちスモールデータ分析にならざるを得なかった。

2つ目は、演繹推論であったために、あいまいさや論理矛盾が許されなかった要因が小さくない。あいまいな推論を行わせるためにファジー推論と組み合わせるなどの方法論が検討されたが、十分な実用化には至らなかった。

3つ目の理由は、エキスパートシステム自身が自ら学ぶことはできなかった

(図表 1) エキスパートシステムとディープ・ラーニング

| 観点 | エキスパートシステム | ディープ・ラーニング |
|------------------------------|--|---|
| 推論方式 | 演繹的推論のみ (帰納的推論は不可能) | 帰納的推論 (演繹的推論も可能) |
| 自動学習能力 | なし (人間がプログラミングする 必要あり) | あり (自らルールやロジックを作 成可能) |
| 使用データ | 少なくとも構わない | 大量データが必要 |
| 使用データ種類 | 構造化データ スモールデータ | 構造化データ + 非構造化データ ビッグデータ |
| フォワード・ルッキング (新しい事象への対応能力) | 過去と同一の事象に対してのみ対 応することが前提 | 将来まだ見たことのない新しい事 象が発生した場合にも、過去の事 象から類推可能 |
| 正確性や 確からしさの度合い | プログラムによる 0 と 1 の判定な ので正確でなければならない。曖 昧さは許さない AI となる | ディープ・ラーニングによる判定 なので、統計と同様に確からしさ によるため、少々の曖昧さは許容 される AI となる |

(出典) 筆者作成。

点が大きいの。何から何までプログラミングしなければならなかったが、現実的ではなかった。

それに対して、いまの AI すなわちディープ・ラーニング型 AI は高性能な IT 環境によりビッグデータ分析が可能になった。そのおかげで帰納的推論が可能になったのである。西垣は、いまの AI は「演繹的に論理の完全性を追求することはあきらめて、結果が概ね合っていればよいとする帰納法の考え方で限界を打破したもの」(西垣, 2016, p.172) とさえ評している。

(3) 統計と AI (機械学習) の違い

管理会計に対して AI を効果的に適用するには、統計分析と機械学習の違いを踏まえておく必要がある。なぜならば、これまで管理会計の実務や研究には統計分析が適用されているが、それと同じように機械学習を適用することができないからである。

まず、機械学習とは何かを定義しておく。機械学習 (machine learning)

は,1990年代からすでに統計学において使われていた。当時の機械学習は、主にニューラル・ネットワークや決定木（decision tree）による統計学としての分類であった。2000年初頭当時は、統計学において、回帰分析や因子分解などの従来の統計分析による手法（以下、統計分析アプローチ）と、機械学習による統計手法（以下、機械学習アプローチ）それぞれの適用される割合は、統計分析アプローチが98%、機械学習アプローチが2%であった（Breiman, 2001, p.199）。現在では、ディープ・ラーニングの実用化が進んでいることから、機械学習アプローチの比率は相当に上がっていることだろう。

足立（2017, p.93）によれば「ディープ・ラーニングの日本語表記は『深層学習』であり、機械学習とは別の技術に思われるかもしれませんが、（中略）教師あり・予測型『ニューラル・ネットワーク』を改良したアルゴリズムで

（図表 2）機械学習の内容とディープ・ラーニングの関係

| 種類 | | 分析手法 | 事例 |
|------|-----------------------------------|-----------------|--|
| 機械学習 | 教師なし・知識発見 グループ分け パターン発見 | 主成分分析（PCA） | 顧客セグメンテーション 購買パターン抽出 インフルエンサー特定 ポジネガ分析 （分析手法は、統計分析アプローチでも適用される） |
| | | 相関分析 | |
| | | アソシエーション分析 | |
| | | コレスポンディング分析 | |
| | | 階層型クラスタリング | |
| | | k-means クラスタリング | |
| | | ネットワーク分析 | |
| | 教師あり・未来予測 分類 回帰 | k 近傍法 | 機械・設備の故障予測 顧客の解約防止 売上予測 不正検知 画像／音声認識 （分析手法は、統計分析アプローチでも適用される） |
| | | 決定木 | |
| | | ランダム・フォレスト | |
| | | ナイーブ・ベイズ | |
| | | 線形回帰／重回帰 | |
| | | ロジスティック回帰 | |
| | | ニューラル・ネットワーク | |
| | | サポート・ベクタ・マシン | |
| | | ディープ・ラーニング | |

（出典）足立（2017, p.93）を基に一部加筆修正。

す。」と明確にしている。機械学習は統計学から発生したことから分かるように、実は機械学習にはもともと「分類」「回帰」「グループ分け」「パターン発見」に属する多くのアルゴリズムがある。図表2の通り、その中の「分類」「回帰」の学習がディープ・ラーニングである。

また、2001年当時でさえ、統計分析アプローチと機械学習アプローチの特徴を踏まえて適用する必要性が述べられていたわけであるから、ディープ・ラーニングの適用可能な現在では、なお一層それらの違いを踏まえて適用される必要がある。とくに、管理会計においては統計分析アプローチの適用が進んでいるため、統計分析アプローチと機械学習アプローチが適材適所で適用されることになる。

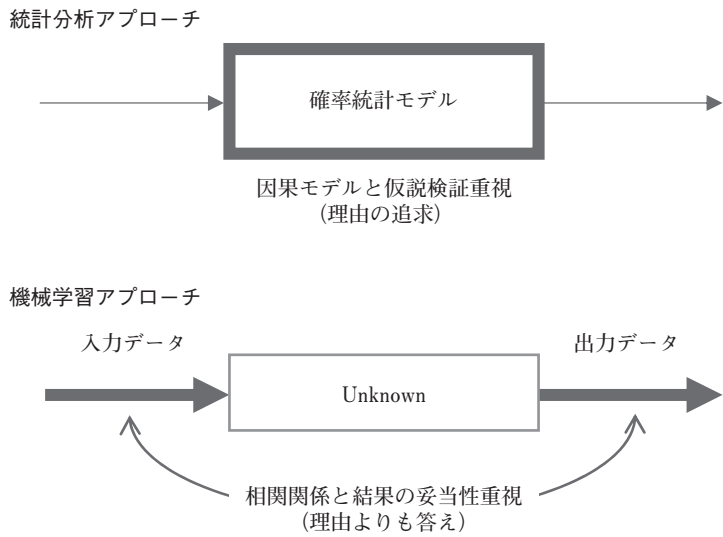
図表3に、統計分析アプローチと機械学習アプローチの違いについて、モデル（アルゴリズム）とデータという観点からそれぞれが追求するポイントを整理した。統計分析アプローチは因果関係を重視し、仮説検証と検定作業を繰り返してアルゴリズムの精緻化を行うものである。すなわち、統計分析アプローチの目的は理由の追求にある。

他方、機械学習アプローチはデータ間の相関関係と結果の妥当性を重視し、モデルの中身は不明（Unknown）でも構わないとするアプローチである。統計分析アプローチはデータが手段でモデル（の精緻化）が目的であり、機械学習アプローチはモデルが手段で出力結果（の妥当性）が目的となる。

統計分析アプローチは、理由に相当する確率統計モデルに対して検定を繰り返して、仮説の正確性を検証する。これに対して、機械学習アプローチは、仮説よりも大量のデータを使ってモデルを外形から確認しながらブラッシュアップさせる方法である。極論すれば、中身のロジックや数式は見ずに機械学習アプローチの予測モデルが作成されると言ってもよい。

機械学習アプローチの最大の特徴は「理由の追求よりも、答えの確からしさの追求にこそ価値がある」との考え方である。換言すれば、「理由はよく分からないが、答えが合っているから構わない」という検証方法が、機械学習アプローチの特徴である。そのため、最近のディープ・ラーニング型AIは、機械

(図表 3) 統計分析アプローチと機械学習アプローチの違い



(出典) 谷守 (2019, p.30) をもとに加筆修正。

学習アプローチであるため、ブラックボックス²と言われるのである。

図表 4 に、Breiman (2001), Mayer-Schönberger & Cukier (2013), Watts (2011), Fawcett & Hardin (2017), 植野 (2017), 依田ら (2016) をもとに、統計分析アプローチと機械学習アプローチの目的や機能を比較した。

2 Breiman (2001, p.199) は、機械学習のようなアルゴリズム・アプローチの処理を Unknown (不明) と表現している。

(図表 4) 統計分析アプローチと機械学習アプローチとの比較

| 観点 | 統計分析アプローチ (確率統計モデル) | 機械学習アプローチ (ディープ・ラーニング) |
|--------------|---|---|
| ① 目的 | <ul style="list-style-type: none"> ・ データがどのようなものなのかを説明すること ・ 実際のデータに基づく、理由・要因・根拠の解明 | <ul style="list-style-type: none"> ・ 大量のデータを分析して、将来を予測すること ・ まだ見えていないデータに対する予測された結果の生成 |
| ② 入力データ仮説有無 | スモールデータ (サンプルデータに基づきモデリングするため、仮説必要) | ビッグデータ (あらゆる大量のデータから特徴量を抽出することにより、仮説不要) |
| ③ 推論方法とモデリング | <ul style="list-style-type: none"> ・ 演繹法によるデータ・モデリング ・ 確率統計モデルの推定 (estimation) | <ul style="list-style-type: none"> ・ 帰納法によるアルゴリズム・モデリング ・ 結果の予測 (prediction) |
| ④ 検証方針 | <ul style="list-style-type: none"> ・ 統計モデルの検定 ・ モデル・パラメータの精緻化 | <ul style="list-style-type: none"> ・ 出力される結果の精度 ・ 予測の妥当性と確からしさ |
| ⑤ 対応アプローチ | <ul style="list-style-type: none"> ・ 因果関係や要因の分析に基づいて、正確性が求められる予測と、それに基づくコントロールを行うアプローチとなる ・ なぜそのような結果になるのかといった理由や要因が詳細に分かれれば、打ち手を講じることができるの思考 <p>「予測とコントロール」アプローチ (predict-and-control)</p> | <ul style="list-style-type: none"> ・ 理由や要因は不明 (Unknown) であっても、そうなることが分かれば即時対応するアプローチとなる ・ なぜそのような結果になるのか分からなくても、実際にそのようになることが分かれば、打ち手を講じることができるの思考 <p>「測定と対応」アプローチ (measure-and-react approach)</p> |
| ⑥ コントロール・ループ | 理由を追求して対策を打つため、主に「フィードバック・ループ」 | 結果に基づき対応するため、「フィードフォワード・ループ」が ^a 可能 |

(出典) 谷守 (2019, p.31) をもとに加筆修正。

(注) Watts (2011, p.216) では偶然など不測の事態への対応が検討されているが、本稿では管理会計におけるコントロール・サイクルを対象に、統計分析アプローチと機械学習アプローチの特徴比較検討のために考え方を参考にした。

2. 管理会計への AI 適用に関する具体的検討

これまで財務会計において実用化されている AI を参考に、管理会計への適用可能性を検討してみよう。検討する管理会計は、谷守 (2018b, p.145) をもとに検討対象の管理会計として誰もが認識している原価見積、予算管理、および意思決定を対象に AI の適用可能性を検討する。

なお、原価見積は、単なる計算ではなく将来予測そのものであり、予算管理

と意思決定会計は現状分析に留まらずに、将来予測型マネジメント・コントロールの機能、および定性評価分析や選択と実行などの経営管理の特徴を持つ。そうした特徴からも適用検討の対象とする価値がある。

(1) 原価見積への AI 適用

一般に、原価計算は材料費、労務費、経費を仕掛品やサービスへ直接賦課するが、残りは製造間接費あるいは加工費として、一定の配賦基準で配賦される仕組みである。このような計算自体は、コンピュータやとくに Excel の登場によって、誰もが簡単に自動化できるようになっている。

その場合であっても、原価計算すべき対象や配賦基準データを分別するには、これまでは人間であった。そのスキルが試されているのが日商簿記試験である。ところが、ディープ・ラーニング型の AI であれば、図表 4 で示した通り、これまでは人手に頼らざるを得なかった分類と回帰が自動化される。

すなわち、与えられた業務上の諸問題に対して、どの計算を当てはめるかといった分類的判断に対しては、いまの AI が十分に威力を発揮できる。それよりもここで研究すべきは、原価見積への AI の適合性である。原価見積とは、日本経営システム協会によれば「過去の経験や知識、ならびに将来の原価発生に関する情報に基づいて、製品やサービスなどの原価を現時点の物価で計算すること（原価評価）とされる。その原価が将来の物価変動や需要・供給の関係の変動に伴って変化するものを予測すること（原価予測）も含む。」とされる。

すなわち、原価見積とは原価の将来予測そのものである。実務では、PDCA（Plan・Do・Check・Action）が重要視されるように、実際原価を計算するのは、あくまでも確認（Check）に過ぎない。それよりも実務で重要視されるのは、すべて期初に始まる原価見積（すなわち、原価の Planning）である。

そこで、AI 適用の可能性を検討するために、原価見積が必要とされる TDABC（Time-Driven ABC；時間主導型活動基準原価計算）と、それをシステムや有形資産にまで発展させた資産活用アプローチの原価計算（谷守，2017

b) をもとに検討する。それぞれ以下の検討の通り、AI によって原価見積の将来予測はかなり高い精度になると推察される。

まず、TDABC は、有識者によって活動ごとの時間（活動ドライバー）を見積る必要がある。簡単にいえば、TDABC はその活動ドライバーによって、ABC（活動基準原価計算）が行われる仕組みと言ってもよい。そのため、これまで ABC に存在したドライバー収集の煩雑さや運用困難性が克服されるという。しかし、逆にいえば、TDABC は有識者のいう活動ドライバーで結果は大きく変わることが問題といえる。有識者が考える時間に対する検証はできないからである。有識者の気分や体調、もともとの経験度合や信用などの人間性が原価計算に大きく影響するという危険な状態にあると言っても過言ではないのではないか。

はたして、その活動時間の見積りに AI が導入できれば、作業や運用の負担を増やさずに、どこか、おそらく逆に一瞬で終わることから自動化・早期化されることになる。さらに、見積り時間自体も、有識者の判断を最後にもってくこともできる。すなわち、AI によって物価動向、経済動向、社会環境の変化、地域顧客の人口動態、沿線の導線の変化、コンペティターの市場占有状態の変化などすべてを入力し、ディープ・ラーニングによって、将来を予測することができるようになる。有識者はそれに対して人間としての経験や定性的な判断を入れて最適な見積り時間を作成できるようになる。

まとめると、TDABC のとくに活動時間を見積る際に、AI が適用されることで、有識者の判断の前に（加えて）さまざまなビッグデータによる将来予測の見積りが可能になる。それによって、有識者は定性的な判断や評価に集中できるようになるので、作業効率が上がるだけでなく、当該有識者ならではのより広く深い洞察力が発揮できるようになる。

つまり、見積りの内容の精度向上に集中して貢献できるようになるのである。さらに、前提として AI を適用しても、現在の IT が前提となって AI が実現されることから TDABC 全体の作業負担を増すものではなく、有識者の作業負担を考えると、逆に効率化されることが予測できる。

以上の、原価見積に関しては、資産活用アプローチの原価計算において、より一層効果を発揮できる。資産活用アプローチの原価計算は、谷守（2017b, pp.114-116）によれば、将来の資産活用度合いに着目した原価計算として定義されている。資産活用型ビジネスにおける費用のほとんどは固定費であることから、顧客の単位で費用を集計する原価計算では十分な納得感を得るのは難しい。

資産活用型ビジネスは、文字通り「資産」を顧客に利用してもらうサービスなので、顧客ごとの費用消費よりも資産活用度合いに着目する方がより納得感の高い原価計算となる。さらに、資産活用型ビジネスであるクラウド・サービス企業の原価計算が実態調査されて、資産活用アプローチの原価計算手順と数理モデルは図表5の通り検討されている。

資産活用アプローチの原価計算では、図表5の数理モデルにある通り、顧客ごとの資産許容量の推定が最も重要である。この資産許容量の推定にAIを活用することで、顧客ごとに将来必要とされる資産量の精度向上が見込める。

(図表 5) 資産活用アプローチの原価計算手順と数理モデル

| | |
|---|---|
| 資産活用アプローチの原価計算手順： | |
| 【資産】 | → 原価計算対象ごとの「資産許容量の推定」(*1) → 【原価計算対象別割当資産】 → 各割当資産にかかる「費用の集計」(*2) → 【原価計算対象】 (*1) 原価計算対象ごとに必要な資産許容量の推定を行う。 (*2) 原価計算対象ごとに割り当てられた資産許容量を維持するのに必要な一定期間内のコストの集計 |
| 資産活用アプローチの数理モデル化： | |
| 原価計算対象 k に必要な資産 j の許容量を見積り (η_{jk})、次にその資産許容量にかかる (あるいは発生する) さまざまな費用を集計する ($fc()$) 構造の数理モデルである。 | |
| $CO_k = \sum_{j=1} fc(\eta_{jk})$ $CO_k \quad : k \text{ の原価}$ $fc(x) \quad : \text{資産許容量 } x \text{ にかかる, または発生するコストの集計関数}$ $\eta_{jk} \quad : \text{資産 } j \text{ の原価計算対象 } k \text{ に対する資産許容量の推定関数}$ | |

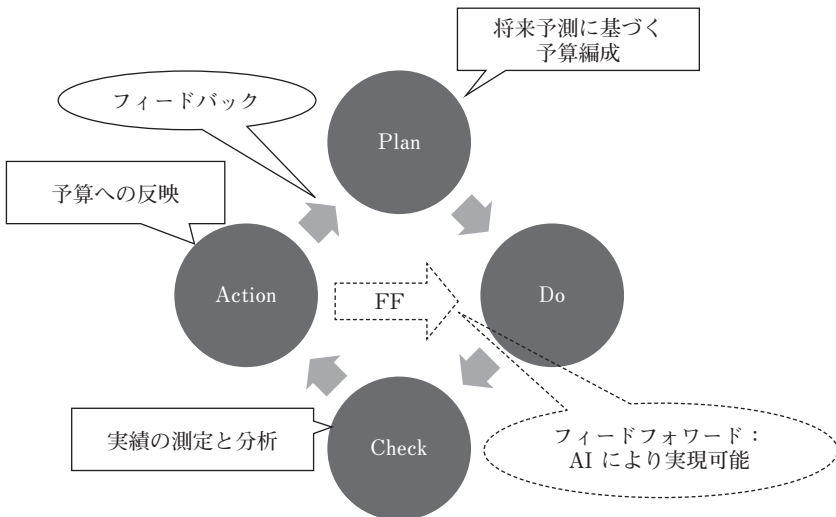
(出典) 谷守（2017 b, pp.114-116）をもとに加筆修正。

(2) 予算管理への AI 適用

予算管理のプロセスは、PDCA サイクルで分解して検討する。期初に将来を予測し予算編成を行う（Plan）プロセス，期中では営業活動（Do），一定期間ごとに実績の測定と分析（Check）プロセス，期末には分析結果をもとに次期予算への反映（Action）プロセスとなる。このように，予算管理は基本的にはフィードバック・コントロール³であるが，AI の適用可能性を，図表 6 にもとづいて検討してみよう。

まず，将来予測にあたってはいまでも統計分析アプローチが活用されている。ただし，実務において適用される統計分析アプローチでは，線形モデルが前提とされることが多い。そのため，予算を月次展開させる場合に，職人芸のような属人的なノウハウが必要とされていることが少なくない。AI によれば，因果よりも相関を重視するので，線形/非線形問わず対応可能である。た

（図表 6）予算管理の PDCA



（出典）筆者作成。

3 ローリング予算であっても短期的なフィードバック・ループといえる。

だし、策定された予算の根拠が不明 (Unknown) になる可能性がある。その場合、予算が示達される各部署から十分な納得感が得られず、目標達成が危ぶまれる可能性もありえる。

また、予算のとりまとめでは、各部署間でのコミュニケーションが重要である。たとえば、ボトムアップ予算は、現場から要求される予算が本部へ報告され、本部ではそれを取りまとめた後に総合予算が作成されるが、実際には予算スラックの問題から、売り上げ予算については低めになり、原価予算は高めになる。そのため、本部では現場の各部署との調整（いわゆるストレッチ）が重要になる。しかし、いまのところ AI では本部と現場との微妙な思いの絡む調整など到底できない。

Frey & Osborne (2013) の研究の通り、現状では行間を読んだり熱い思いで説得したりするネゴシエーションやコミュニケーションの機能は人間の足下に及ばない。したがって、AI による予算とりまとめを自動化することは当面難しいと言わざるを得ないし、仮にいまのまま自動化が行われると、予算スラックが見抜けない上、実績の予算達成も非常に難しい状況になりかねない。AI には最適解は算定できたとしても、心を通わせるとか本音で語る機能は全くできない。

特に、決算予想・決算見込・落着予想・落着見込など決算期末に向けてのほんの数か月先の短期予想作業については、ほとんどの企業で属人化しており、AI が効果的に機能することが期待される。これらは、期中に現在進行形で将来予測を行い、推進策や予防策などの打ち手を講じる作業である。そのため、当初計画に戻る訳ではないことからフィードバックではなく、フィードワードとなる（図表6の矢印FFを参照）。現状の会計ソフトや各種ERPでもいまだ実現できていない機能である。

会計ソフトやERPで決算予想が実現できなかったのは、非線形の予測であること、理由や要因が不明であったこと、そして非構造化データが取り扱えなかったことによる。それらが、AI適用によって以下の通り解決できる。

✓ 理由や要因が不明でも、データから学習可能

✓ 構造化/非構造化データを持つビッグデータをもとにした学習

✓ 機械学習アプローチは非線形の関係性で予測可能

すなわち、これまでの統計では、要因の説明のつかない予測を行うための仮説モデルの作成は容易ではなかった。それに対して、いまの AI であれば、過去に基づいて学習した内容で予測することが可能である。期末に向けてリアルタイムにさまざまなデータ（ビッグデータ）を取り込むことによって、高速にフィードフォワード型の見込み算定が可能になり、期末の予算達成に向けて前向きな打ち手を講じることができるようになる。

また、この AI の将来予測型マネジメント・コントロールは、リスク管理に効果が発揮できるものと期待される。たとえば、銀行で導入が進むリスクアペタイト・フレームワーク（RAF）⁴がある（金融庁、2015）。リスクアペタイト・フレームワークはリスク回避スタンスの概念ではなく、必要に応じて適切な範囲内でリスクを取ることを推奨する経営管理概念である。

現状の銀行管理会計は財務会計とリスク管理それぞれを補完する役目を担っているが、会計に対するフィードバック機能であった。いまの銀行管理会計におけるリスクには目標も計画もなく、あるのはリスク限度やリスク枠のみであった。現状の銀行管理会計における統合リスク管理では、リスクは回避すべきものであって、リスクのマネジメント・コントロールまでは実現できていなかった。

一方、2013年に金融安定化理事会より金融危機後の銀行に対するコーポレート・ガバナンス強化の議論の一環として提唱されたリスクアペタイト・フレームワークは、リスクに対して取るべき目標水準を策定するガイダンスとなっている（FSB、2013）。目標リスクを水準として経営していくプロセスは、実績値と目標額との差異分析の結果を予算や計画にフィードバックするこ

4 リスクアペタイト・フレームワークとは「自社のビジネスモデルの個性を踏まえたうえで、事業計画達成のために進んで受け入れるべきリスクの種類と総量を『リスクアペタイト』として表現し、これを資本配分や収益最大化を含むリスクテイク方針全般に関する社内の共通言語として用いる経営管理の枠組み。」（金融庁、2015, p.16）とされる。

とに留まらない。

本来、リスクのコントロールはフィードバック機能よりも、あらかじめ予防的に手を打っておくフィードフォワード機能の方が有効である。つまり、リスクは発生してしまうと損失として現実化するのみであるが、発生しないようにコントロールすることこそ、より高い利益を上げることができるのがリスクの特徴である。とくに、銀行の信用リスクは収益との相関性が高く、リスクを単に減らすコントロールを行ってしまうと収益も減少する危険性がある。

したがって、リスクのマネジメント・コントロールでは、結果をみてから対策を講じるだけではなく、将来起こりうる外的要因や対象変化に対して最適化を目指す運営が求められる。リスクの目標水準に近づくようにリアルタイムでリスク発生を予想しつつ監視を怠らずに打ち手を講じておくことが重要である。すなわち、銀行管理会計におけるリスクのマネジメント・コントロールにおいては、フィードバック機能だけでなくフィードフォワード機能が重要になる。

現状の銀行管理会計におけるリスク調整機能は、バックワード・ルッキングで処理のため、フィードバック機能でマネジメント・コントロールするまでであった。しかし、AIの適用によって銀行管理会計は、図表7の通りリスクと会計が明細レベル、かつフォワード・ルッキングな情報によって財務会計で計算されることとなる。そのため、銀行管理会計においては財務とリスクの統合化の役目よりも、フォワード・ルッキングな明細レベルの会計情報によって、フィードフォワードにマネジメント・コントロールすることが可能になると推察できる。

以上の通り、AIによって、過去のデータに基づいて学習した内容で予測することが可能になる。期末に向けてリアルタイムにさまざまなデータ（ビッグデータ）を取り込むことによって、高速なフィードフォワード型の見込算定が可能になり、期末の予算達成に向けて効果的な打ち手を講じることが可能になる。

「定性評価分析」のプロセスは、文字・音声・画像などの非構造化データによる企業の理念やカルチャーに基づき過去の意思決定も参考にしながら判断する必要がある。インタンジブルズ情報を含むビッグデータに対してAIを適用することによって「定性評価分析」プロセスの自動化が期待できるのではないか。

しかし、「1. AIの進化と特徴」で明らかにしたようにブラックボックスから出力された結果だけでは、その結果の理由や根拠が不明である。そのため、「選択・実行」プロセスにおいては、AIのブラックボックス化がとくに大きな課題となる。

「定性評価分析」プロセスを通していくつかの代替案のなかから推奨案が提示され、その推奨案が最適かどうかを「選択・実行」プロセスで人間が判断する必要がある。最終的な判断を行う際に、なぜその代替案が推奨されるのかという理由や根拠が求められるからである。

「選択・実行」プロセスにおいては、AIのブラックボックス化問題が浮き彫りになる。統計分析アプローチとの違いで検討した通り、AIは予測結果の精度向上を第一の目的としているため、アルゴリズム（モデル）は計算の手段でしかない。そのため、AIのモデルは非常に複雑になり、結果的に人間には理解不能になり、ブラックボックスとみなされてしまうのである。

さらに、AIのブラックボックス化問題の根源は、AI適用によって責任の所在が不明確になること、すなわちアカウントビリティ⁶が不明確になる⁷ことである。短期間の業務的意思決定の場合であっても、人の生命にかかわるようなリスクの大きな意思決定には、アカウントビリティの確保が求められる。そ

5 最適在庫量問題のように与えられた条件をもとに最適解を算定するのは機械学習でも得意分野である。日立製作所ではAIによる在庫発注量管理を製品化している。これは、最適組み合わせ問題に対して機械学習が統計の一手法として適用されている事例である。

6 この場合のアカウントビリティは、会計責任の意味だけでなく、安藤ら（2018）のいう受託責任の意味もある。

7 なぜならば、AIが企業を経営している訳ではなく、人間が経営しているからである。本稿では、SF映画や小説の世界ではなく、現実の実務への適用を検討している。

のため、このような場合でもブラックボックス化が課題となる。

また、自動運転車のように短時間の連続的な業務的意思決定の場合には、AIの方が人間より格段に速く疲れることなく連続して当該意思決定を実行できるため、AIの実行の後に人間が最終判断を行うことになる。すなわち、AIによる業務的意思決定が行われた後にその結果を事後的に評価（事後判断）するのである。ただし、自動運転の場合には、業務的意思決定が連続して行われるので、途中の一定時点でAIによる高速のフィードフォワード・コントロールが行われている状況にあるといえる。

そこで、意思決定会計へのAIの適用により実現が期待される機能と、そのための解決すべき課題は図表8の通り、まとめられる。

3. AI 適用に関する考察

原価見積、予算管理、および意思決定会計に対するAIの適用可能性を検討してきた。その結果、管理会計において新たな機能が期待できると同時に、その実現のためにいくつかの課題も考えられる。

（図表8）意思決定会計へのAI適用可能性

| | AIにより実現が期待される機能 | AI適用にあたっての課題 |
|-------------|--|--|
| 業務的 意思決定 | 予測結果による即時自動化対応 ⇒ 時々刻々と変わる場面や状況に 応じた「フィードフォワード・ コントロール」の実現 | ・リスク小の場合： 事後意思決定理由の確認機能や意思決定トレース 機能などが必要 ・リスク大の場合： 途中での承認手続き機能（インタラプション機 能）などが必要 ⇒ アカウンタビリティの確保 （ブラックボックス化問題対処） |
| 戦略的 意思決定 | 過去のさまざまな意思決定のケ ースを参考にした意思決定や、企業 外部の社会経済情報・口コミ情 報・SNS情報などビッグデータ をもとにした定性的な評価分析 ⇒ ビッグデータ分析による 定性的意思決定の実現 | ・責任所在の明確化のため、AIによる意思決定後 の選択案に対して、最終的には人間による意思決 定（AI結果の承認）が必要 ・そのためには、経営会議で議論可能なAIの意思 決定根拠が必要（理由や根拠のホワイトボックス 化） ⇒ アカウンタビリティの確保 （ブラックボックス化問題対処） |

（出典）谷守（2019, p.34）をもとに加筆修正。

(1) AIによって実現が期待される管理会計

構造化データだけでなく、自然言語や画像や音声も広く対象にした「現状分析」を誤りなく自動的に行う機能や、過去のあらゆる事例をもとに漏れなく自動的に「問題を把握」する機能などについては、すでに一部の会計ソフトで実現されているAI機能である。したがって、現状分析と問題の把握に対するAIの適合可能性はかなり高いと考えられる。

その他、予算管理と意思決定会計へのAI適用検討の結果から、今後実現が期待できる管理会計ならではの機能が少なくとも3点あげられる。

第1に、リアルタイムな「フィードフォワード・コントロール」の実現である。期中でも目標達成のための打ち手や、期末までに事前にリスクへの予防が行えるようになるので、経営の機動性やスピードが増す。

第2に「ビッグデータによる定性的評価分析」の実現である。企業外部の社会経済情報・口コミ情報・SNS情報などビッグデータをもとにした定性的な評価分析が可能になる。過去のさまざまな意思決定のケースから、事例として自動検索も可能になるだろう。

第3に「AIによる最適資源配分」の実現である。AIによって高速かつ効率的・効果的に最適組合せ問題の解が算出できる。予算管理や意思決定会計の「最適資源配分」に対して、動的計画法で解くよりも効率的かつ効果的に最適解を得ることができる。

以上の通り、AIによる管理会計への適用による完全自動化は、まだしばらくはかかるだろう。しかし、完全でなくとも、全く疲れを知らず、見落としなどのミスもほとんどない「現状分析」や、新たな将来予測のための「統計分析」の手法の1つとしての位置づけであれば、いまでも十分に実用可能である。

現時点では、AIによる現状分析と将来予測の結果をもとに、人間が定性評価と行動に変える方法が現実的である。そのレベルであっても、AIであれば、IoTによるリアルタイムの情報をもとに、即座に推奨可能な行動支援情報を提示可能である。つまり、いまのAIを適用するだけで、フィードバックだ

けでなく、フィードフォワードが可能になる。

結論としては、現状の管理会計のプロセスを、現状分析、定量的将来分析、定性的将来分析、実行（アクションへの変換）と分けて検討した結果、現状分析と定量的将来分析に対しては、現在の AI の適用によって自動化され、結果の品質や精度が高くなり、経営にとって相当に大きな効果が十分に期待できる。

しかし、定性判断と実行については、要因の説明力の強化が求められるが、そのための本質的な課題は、基本的な人間の社会生活を送る上での良識や、地域や業界における習慣や文化を学ぶ必要がある。莫大なデータ量と学習時間が求められるので、数年では困難だろうと思われるが、10 年後は分からない。今後の管理会計からの AI 研究の進展次第である。

(2) AI 適用のための評価上の課題

経営の意思決定において、判断根拠が示されなければ、実際に行動に移せない可能性がある。すなわち、AI を管理会計へ適用する場合には、判断または予測された出力結果の理由や要因のブラックボックス化が最大の課題となる。それに対して、次の 3 点の対策が考えられている。

第 1 に、ブラックボックス化されていても構わない管理会計機能への適用を行う方法がある。たとえば、リアルタイム性が要求される場合や、予測が外れたり意思決定が間違っていたりしても影響リスクが小さい場合などには、事前に理由や根拠は必要ではない。AI の意思決定結果が事後検証できれば十分であり、それよりも早く答えを出す方に価値がある。

第 2 に、人間にとって分かりやすい要因説明自体を AI に学習させる方法が考えられる。人間が納得できる要因説明方法を過去の事例から学ばせるのである。将来予測や意思決定の際に、当該企業で戦略上最も重視している変数や変動要因の多い変数を学び、そこから状況に応じて最も納得しやすい自然言語で理由を出力する方法を開発すべきである。

第 3 に、ホワイトボックスとブラックボックスの混在するハイブリッドモデ

ル（植野，2017,p.15）を構築することが考えられる。ホワイトボックスは演繹法であり，それと帰納法であるAIを組み合わせた方法である。このAIのディダクシオン化（演繹化）やハイブリッド化は各ベンダーで研究中である。

ただし，高速のIT環境でビッグデータを活用することができる時代となり，管理会計をもとに経営を行う人間自身の考え方が「理由よりも結果」へシフトする可能性がある。グローバルなネット環境で多様な情報が24時間瞬時に飛び交う複雑系の時代においては，要因分析の価値はそれほど高くない。要因分析よりも反射神経的に間違わないように対応することの方が重要であり，前向きに実行する意識の方が最優先されるようになるのではないか。

（3）AI適用の将来性

以上のことから，管理会計へのAIの適合性はかなり高いといえる。財務会計の正確性，監査可能性，検証可能性よりも，結果の適合性や将来志向性が重視される管理会計の方がAIの結果志向が適合しやすいとも言える。

さらにいえば，管理会計の代表的なBSC（balanced scorecard）では，戦略的な仮説が重要であるが，その検証は不能である。そもそも統計的な検証は不可能であるし，もともとそういった正確性を期す統計上の仮説ではない。あくまでも，戦略的な方向付けを行うためのストーリーや全員で意識合わせするためのスローガンのようなものである。

また，統計は「風が吹けば桶屋が儲かる」のモデルの正確性を検証し，さらなるモデルの精緻化を行うものであるが，機械学習アプローチではモデルのアウトプットの妥当性を高めることが目的であり，アルゴリズムの精緻化は副的なものとなる。すなわち，統計は結果よりもその要因や理由の解明の方が目的であり，機械学習アプローチは結果こそが目的である。

ディープ・ラーニングが実用化されたおかげでAI自ら特徴量抽出が可能になった。そのおかげで自動的にアルゴリズムが構築されることになり，インプットデータさえあれば予測結果を瞬時に出力できるようになった。統計では，最初に仮説モデルが必要であり，そのモデルの統計的価値が測られて，よ

りモデルの精緻化が図られていくことになる。あくまでも過去のアウトプットに基づく同様の結果を出すためのモデル構築である。

もともと、管理会計の評価は容易ではない。たとえば、ABC によって商品別に原価を計算した場合の検証では、いわゆる“納得感”なるものが使われることが少なくない。ABC は活動によって跡付けられる原価であるため、当然ながら活動量に比例して原価が賦課される。複数の活動量を商品原価の検証に使うのは、計算上の正確性を確認しているに過ぎず、それではシステムテストしていることと変わらない。

実務のとくに経営レベルで管理会計に対して最終的に求める検証とは、計算の結果であるアウトプットがはたして実務上納得できるかどうかにある。このような管理会計における、ある種観念的とも捉えられる「納得感による判断」しかないという検証方法は、機械学習アプローチによる結果の検証が妥当であり、大いに期待できる。

おわりに

AI の管理会計への適用を研究すると、「管理会計の機能とはそもそも何なのか」ということを考えることになる。AI の適用のためには、管理会計の機能が記述できていなければ不可能だからである。それはつまり、AI 化を検討することによって、管理会計の本源的な機能を研究することになるのである。

そういった意味で、AI による管理会計の適用を研究することによって、本来の管理会計研究のあり方やその方向性を見直すことができる。それは「人工知能を研究することは、人間の脳を研究すること」と同様である。

また、会計研究では実証分析研究が活発であるが、統計分析だけではなく、今後は機械学習による研究も期待される。機械学習アプローチの研究であれば、ビッグデータによって工学的に研究が行えるようになる。実務での適合性が強く求められる管理会計研究においては、統計分析アプローチだけでなく、機械学習アプローチによる研究もとくに有効に機能するのではないだろうか。

最後に、本稿は AI の管理会計適用に関する理論的考察に過ぎない。現在、

実際にディープ・ラーニングへの適用の多いAI言語の1つであるPythonを使って実際に管理会計へのAIの適用システムをプログラミング中である。実際にAIのモデルを管理会計へ適用して、その結果を評価するアプローチによって実証研究する予定である。

(付記)

本研究はJSPS科研費JP18K01921の助成を受けた成果の一部である。

参考文献

- 足立悠 (2017) 「『ディープ・ラーニング』 アルゴリズムあんちょこ」『Interface 2017 年3月号』43(3):92-98 頁。
- 安藤英義編著・桃田龍三・建部宏明・石原裕也・菱山淳・田中孝治 (2018) 『会計における責任概念の歴史：受託責任ないし会計責任』中央経済社。
- 植野剛 (2017) 「機械学習とは何か？」『証券アナリストジャーナル』55(8):6-15。
- 金融庁 (2015) 「平成27事務年度 金融行政方針」『金融行政方針』。
- 情報処理推進機構 (2017) 『AI白書：人工知能がもたらす技術の革新と社会の変貌』角川アスキー総合研究所。
- 谷守正行 (2015) 「関係性をもとにした顧客別原価計算研究：銀行リテール・ビジネスにおける顧客別ABCの課題への対応」『原価計算研究』39(2):1-12。
- 谷守正行 (2017a) 「銀行の顧客別管理会計の現状と今後：事例研究に基づく考察」『専修会計学研究』(43), 53-73 頁。
- 谷守正行 (2017b) 「資産活用アプローチの原価計算：資産活用型ビジネスからの知見とモデル化」『原価計算研究』41(2):98-110 頁。
- 谷守正行 (2018a) 「銀行管理会計の現状と今後の方向性」『會計』193(1):80-93 頁。
- 谷守正行 (2018b) 「管理会計へのAI適用可能性に関する一考察」『専修商学論集』(106):135-148 頁。
- 谷守正行 (2019) 「管理会計へのAIの適用可能性」『企業会計』71(2):29-36 頁。
- 西垣通 (2016) 『ビッグデータと人工知能：可能性と罣を見極める』中公新書。
- 松尾豊 (2015) 『人工知能は人間を超えるか：ディープラーニングの先にあるもの』KADOKAWA。
- 依田祐一・水越康介・本條晴一郎 (2016) 「AIを活用したユーザーニーズの探索プロセスにおける「結果」と「理由」に係る一考察 ～Amazon.comとGoogleをもとに～」『立命館経営学』55(3):105-127。
- Breiman, L. (2001) Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). *Statistical Science*, 16(3):199-231.
- Fawcett, T & D, Hardin (2017). Machine Learning vs. Statistics: The Texas Death Match of Data Science. Silicon Valley Data Science BLOG. (<https://www.svds.com/machine-learning-vs-statistics/>) (2018年12月1日閲覧)
- Frey, C. B., & M. A. Osborne (2013). The Future of Employment: How Susceptible

Are Jobs to Computerization? (<http://www.oxfordmartin.ox.ac.uk/publications/view/1314> ; 2019 年 1 月 8 日閲覧)。

FSB (2013), *Principles for an Effective Risk Appetite Framework*, Financial Stability Board.

Mayer-Schönberger, V., & K. Cukier (2013). *Big Data : A Revolution That Will Transform How We Live, Work, and Think*, Houghton Mifflin Harcourt. (斎藤栄一郎訳 (2013) 『ビッグデータの正体：情報の産業革命が世界のすべてを変える』講談社。)

Watts, D. J. (2011), *Everything is Obvious : Once You Know the Answer*, New York, Crown Business. (青木創訳 (2012) 『偶然の科学』早川書房。)